

From implicit skills to explicit knowledge: a bottom-up model of skill learning
Ron Sun, Edward Merrill, Todd Peterson
Cognitive Science 25 (2001) 203-244

Abstract

- ・ この論文ではスキル学習のモデル CLARION について述べる .
- ・ 多くの高次レベルのスキル学習
トップダウンアプローチ (宣言的知識 手続き的知識)
- ・ CLARION のスキル学習
ボトムアップアプローチ (手続き的知識 宣言的知識)
- ・ オンラインの敏感な学習を行うために 局所/分散表現を組み合わせた dual-representation framework(Sun, 1995)を用いる .
- ・ 機雷原ナビゲーションタスクにおいて , 人のデータとモデルの比較を行い評価する (Fig. 1) .

1. イントロダクション

- ・ スキルの獲得と使用は人間の活動の主要な構成要素であり , 認知科学において , スキル学習の研究は主要なテーマである .
 - 数学 , パズル , 初等幾何学 , LISP プログラミング
- ・ 認知スキル
シンプルなモータームーブメント ~ 高次の知的スキル
- ・ 研究の動機
 - 低次の認知スキルのモデル化にはほとんど注意が向けられない
 - ほとんどのスキル学習モデルはトップダウンのモデルである
多数の事前知識を必要としない学習のボトムアップモデリング

2. モデル化

2.1. 背景

モデル化における根拠

- ・ 手続き的と宣言的知識の区別
- ・ スキル学習のオンライン性
- ・ 手続き的から宣言的知識へ進行するボトムアップ学習
これらを本研究のモデルで示す

手続き的知識 vs. 宣言的知識

- ・ 宣言的知識と手続き的知識の区別
 - 宣言的知識
 - ・ 意識的にアクセス可能
 - ・ 学習速度の効率化
 - 手続き的知識
 - ・ 意識的にアクセス不可能
 - ・ 効率的
- ・ 学習と認知における多くの理論でこの区別は行われている (Anderson, 1976, 1983, 1993; Keil, 1989; Damasio et al., 1994; Sun, 1994) .
 - Smolensky(1988)
概念 (明らかにアクセス可能) と sub 概念 (アクセス不可能)
 - Dreyfus and Dreyfus(1987)
分析的思考と直感的思考

オンライン学習

- ・ 人の学習
 - 段階的
 - 継続的 (on-going)
 - タスクの実行と同時に生起する
 (Dominowski(1972), Dominowski and Wetherick(1976), Medin et al.(1987), Nosofsky et al.(1994))
 Anderson(1982, 1983)や Rosenbloom et al.(1993)のトップダウン学習モデルへ応用

ボトムアップ学習

- ・ トップダウン学習
 - 宣言的知識/手続き的知識を区別した従来のスキル学習の研究は、トップダウンのアプローチを仮定している
 学習者は最初に領域における多くの顕在的な宣言的知識を獲得

 練習を通して、宣言的知識を手続き的な形式に転換
 - Anderson(1982)
 インストラクションからの顕在的な宣言的知識をプロダクシヨナルールへと変換し、その後の練習を通して洗練化される
 - Rosenbloom et al.(1993)
 手続き的知識 チャンキング
 - Jones and VanLehn(1994)
 手続き的知識は、練習を通して得られた統計的な情報を基礎に、ア・プリオリに与えられたルールの条件を修正することを通して発達する。
 定理問題、テキスト編集、LISP プログラミング、数学などの多くのタスクで応用
- ・ ボトムアップ学習
 - ダイナミックコントロールタスク (Berry and Broadbent, 1988)
 - 人工言語学習 (Reber, 1989)
 - 連続的反応課題 (Willingham et al., 1989)
 学習は手続きから宣言的知識に進行する可能性がある

2.2. The CLARION model

モデルのインプリメンテーション

- ・ CLARION (Connectionist Learning with Adaptive Rule Induction ON-line) モデル意思決定アルゴリズム
 1. 現在の状態 x を観察する
 2. **ボトムレベル**において、状態 x において可能な行動 a の各値を計算する
 $Q(x, a1), Q(x, a2), \dots$
 3. 現在の状態 x (ボトムレベルからあがってくる) と **トップレベル**において存在するルールに基づいて、可能なアクションのすべて ($b1, b2, \dots$) を見つける
 ランダムに一つが選択される
 4. トップレベルまたはボトムレベルのどちらかの結果を**確率論的に選択**することによって、適切なアクション a が選択される
 5. アクション a の実行、次の状態 y を観察、強化 r
 6. 適切なアルゴリズムに基づき、フィードバック情報をもとにボトムレベルをアップデートする
 7. ルールの構築、洗練、削除に対する適切なアルゴリズムを使用し、トップレベルをアップデートする
 8. ステップ 1 へ

Fig. 3 (Q-Learning)

- ・ ボトムレベルから宣言的知識へのルールの抽出 (the Rule-Construction-Refinement algorithm)
 - ルールの抽出
 - ・ ボトムレベルにおいて決定されたアクションが成功したなら (幾つかの基準をクリアしたなら)

- ・ エージェントはルールを抽出し
- ・ トップレベルのルールネットワークへルールを追加する .
- ルールの適用の結果からのルールの変更
 - ・ 成功：より一般化するようにルールの条件を一般化する (“ 拡張 (expansion) ”)
 - ・ 失敗：ルールの条件はより特殊化し，排他的になる (“ 縮小 (shrinking) ”)
- ・ エピソード記憶
 - 最近の経験を保持する記憶
 - (インプット，アウトプット，結果) の形をとる

Fig. 2 (CLARION モデル)

Fig. 4 (トップとボトム)

3. 比較検討

3.1. 実験方法

- ・ 課題：機雷原ナビゲーション課題 (Fig. 1)
 - 潜水艦を操縦し，機雷原を避けながらターゲットに到達させる .
 - 機雷の配置はエピソード毎にランダム配置
 - 現在の情報が幾つかの計器が表示されたコンピュータスクリーンに提示された Fig. 5
 スクリーン下：ソナーゲージ (地雷がどの程度近いかを表示する)
 真中：方位ゲージ (ターゲットの方向を示す)
 左上：燃料ゲージ (燃料がなくなるまでの時間)
 右上：距離ゲージ (ターゲットまでの距離)
 - 被験者は潜水艦をナビゲートするためにジョイスティックを用い，以下の行動を行う .
 - (1) どの程度ターンするか？
 - (2) どの程度早く動くか？
 - タイムプレッシャー
被験者には 2 5 秒与えられた .
 - 最終状態は以下の 3 つである
 - (a) ターゲットに到達する (成功)
 - (b) 地雷に触れる (失敗)
 - (c) 燃料を使い切る (失敗)
- ・ 教示
 - I. 潜水艦を機雷原を通りながらターゲットにたどり着かなければならないことを想像してください . 以下の機器の操作説明書が利用できます .
 - (1) ソナーゲージはどの程度地雷が近くにあるかを表示します .
この情報はあなたの左 4 5 度から右 4 5 度の範囲の 7 つのエリアを表示します .
地雷はソナーによって検知され，各方向においてサークルとして表示される .
サークルの大きさがその方向に地雷が近いことを示しています .
 - (2) 燃料ゲージはガスを使い切るまでの時間を表しています .
あなたは，タスクを完了するために燃料を使い切る前にターゲットに到着する必要があります .
 - (3) 方位ゲージはあなたのいる場所からターゲットがどの方向にあるかを示しています
 - (4) 距離ゲージはあなたのいる場所からターゲットまでの距離を示しています .
 - II. 各エピソードの始めに，あなたは機雷原のはじめにいます，そして，ターゲットは反対側にあります .
燃料がなくなる前に機雷原を通してターゲットに到着することがあなたの課題です .
エピソードの終わりは，
 - (a) ターゲット到達する (成功)
 - (b) 地雷に接触する (失敗)
 - (c) 燃料がなくなる (失敗)

です。

III. ここで潜水艦の操作について示します（ジョイスティックを使って操作説明）。

- ・ 被験者が置かれる環境
 - エピソード毎に変化する
 - シビアナタイムプレッシャーとわずかな教示
- ・ トレーニング条件
 - (1) 通常トレーニング条件
連続した5日間で20エピソードを5ブロックずつ（1日100エピソード）行う。
 - (2) 発話トレーニング条件
選択されたエピソードのゆっくりした再生と、エピソード中に考えていることの発話を求めた。
一つのグループは、1、3、5日に最初の20エピソードと最後の20エピソードに対して発話。
もう一つのグループは5日のみ発話。（タイムプレッシャーがあるため、同時発話ではない。）
 - (3) 過剰発話トレーニング条件
1セッションの20エピソードのうち15エピソードにおいて発話
エピソードの再生をエピソード終了後に直ちに行った。
 - (4) 2重課題条件
カテゴリ決定課題を行うのと同時にナビゲーション課題を行った。
カテゴリ決定課題：被験者は3秒ごとに5つの意味的カテゴリからの事例を聞かされ、ターゲットカ
テゴリが提示されたときには発話で答えることが求められた。
 - (5) 転移条件
被験者は、2つの連続したブロックにおいて80%の成功率に達するまで、30の機雷がある機雷原
でトレーニングを受けた。
一つのグループはシングル課題の条件、他のグループは2重課題の条件で行われた。
転移課題では、両条件の被験者が60機雷の機雷原でのナビゲーション課題を行った。
- ・ トレーニング条件の理論的根拠
 - (1) 発話
発話により顕在的になる。それにより、トップレベルのメカニズムがより働き、パフォーマンスが向
上すると考えられる（Stanley et al., 1989; Willingham et al., 1989）。
 - (2) 過剰発話
過剰発話により過剰に顕在的になる。それにより、トップレベルのメカニズムがなお一層関与するた
め、ボトムレベルを抑制し、パフォーマンスを低下させると考えられる(Reber, 1989; Schooler et al.,
1993; Berry and Broadbent, 1984)。
 - (3) 2重課題
2つ目の顕在タスクによって気がそれるため、トップレベルのメカニズムはプライマリタスクで利用
しにくくなり、パフォーマンスを低下させる(Dienes and Fahey, 1995; Nissen and Bullemer, 1987)。
 - (4) 2重課題における転移
学習は2重課題ではより潜在的になるため、転移を制限される(see, e.g., Dienes and Berry, 1997)。

3.2. モデルのセットアップ

- ・ インพุットレベル
被験者がスクリーンにおいて見るだろうものと同一のもの
燃料：1ノード（たくさん，すこし）
距離：1ノード（遠い，近い）
方位：6ノード（極左，左，まっすぐ，右，極右，真後ろ）
ソナー：各ソナーに5ノードずつ（各レンジは，遠く～近く）
計43ノード
- ・ アウトพุットレベル

被験者が行った2つの行動と同一のもの

方向転換：5ノード（左，少し左，まっすぐ，少し右，右）

スピード：（とても速く，速く，遅く，停止）

- 強化

段階的報酬：ターゲットへの距離の変化に比例

最終報酬：エージェントの成功/失敗によって決定

もしエージェントが割り当てられた時間内にターゲットにたどり着いたら，1

もしエージェントが時間をオーバーしたり爆発したら，距離に反比例

- ボトムレベル

Q-Learning

- トップレベル

“状態 行動”

3.3. 人とモデルの比較

10人の被験者データと10のモデルデータが比較された。

学習における二重課題の効果

二重課題は，セカンダリタスクの高い顕在的性質によって，トップレベルの顕在的学習のパフォーマンスの妨げになる。

潜在プロセスよりも顕在プロセスでより妨害する（Stadler, 1995; Nissen and Bullemer, 1987; Szymanski and MacLeod, 1996）。

- 通常条件と二重タスク条件の比較

- 通常条件との比較で潜在的プロセスの働きをより反映させた

各条件において，各被験者ごとに500エピソードのパフォーマンスデータを得た。

500エピソードは20エピソードごとの25ブロックに分割された。

Fig. 6

- ANOVA（人 vs. モデル × 単独 vs. 二重）

単一 vs. 2重課題：主効果が有意（ $p < .01$ ）

グループとタスクタイプ間のインタラクションなし

人とモデルの傾向は同じ

トップレベルの顕在的プロセスと宣言的知識が学習の向上を助けたことを示している。

- 転移における二重課題の効果

- 二重課題条件の効果のさらなる説明のため，トレーニング後のパフォーマンスの転移を比較した

- 宣言的知識の獲得が学習されたスキルの転移を助けることを考えると，二重課題は単一課題の転移よりもパフォーマンスが悪くなると予想

Fig. 7

- 二重課題の転移よりも有意に単一課題での転移が起こった

- ANOVA（人 vs. モデル × 単独 vs. 二重）

単一 vs. 二重の有意な主効果（ $p < .05$ ）

グループとタスクタイプの間インタラクションなし

人とモデルの傾向は同じ

トップレベルにおいて獲得された宣言的知識は学習されたスキルの転移を促進することを助ける

- 発話の効果

- 発話は学習を促進させると考えられている

- 発話条件は，非発話条件と比べて，被験者の顕在プロセスの働きをより一層反映させる傾向がある（Ahlum-Heath and DiVesta, 1986; Squire and Frambach, 1990; Stanley et al., 1989）

- 発話した被験者の 2 つのグループ（最初の日に発話したグループと 5 日目に発話したグループ）のパフォーマンスを比較

Fig.8

- ・ 最初の 4 日は発話の効果を確認するための
 - ANOVA (4 (日) × 2 (人 vs. モデル) × 2 (発話 vs. 非発話))
人とモデルは発話によってパフォーマンスが有意に増加した ($p < .01$).
2 つのグループに対する発話の効果に差はなかった。
人とモデルの傾向は同じ
- ・ 過剰発話の効果
 - すべての被験者は 25 エピソードの最後までパフォーマンスが増加しなかった。
ボトムレベルの潜在的学習において、トップレベルによる強い干渉が影響した
 - もし、ボトムレベルが正確に働いているなら、学習のパフォーマンスが一般的によりよいはずである（二重課題条件における人のパフォーマンスを参照、二重課題ではボトムレベルの潜在的学習のパフォーマンスが反映されている）。
 - モデルでも、ルール学習の閾値を操作することにより再現した。

3.4. ボトムアップ学習を暗示する発話

被験者からの発話データからボトムアップ学習の存在が示唆された。

- ・ 最初、被験者は特別なルールやストラテジの意識的な自覚なしに課題を行っていた
- ・ 徐々に、課題を行うことを通して、被験者はアクションルールを顕在的に理解することが可能となった。

3.5. さらなる分析

モデルと人の行動軌跡の対応

- ・ 人とモデルの行動軌跡の類似点
 - (1) 機雷のレイアウトにより難易度が変わる。優しいレイアウトでは両群で優しく、難しいレイアウトでは難しかった。
 - (2) 機雷原に入る前と出た後は“ゴールに向かったまっすぐなパス” 好んだ。
 - (3) 反対向きのコースを取ることは滅多になかった。機雷原に入って最初の軌跡は、爆発するか時間切れになるまでまっすぐすすんだ。両グループとも同じようなバイアスがある。

CLARION と人のパフォーマンスが同様のプロセスの結果であることを示している

ルール学習の人のデータとの対応

- ・ 被験者のデータを用いて、モデルの強化プロセスとルール構築の詳細については検証できなかった人間の低次のスキル獲得に対して十分正確な方法論が欠如しているため。

単一レベルのモデルの可能性

- ・ トップレベルを除いた、ボトムレベルのみの単一レベルで人のデータを説明できるか？
 - 人のデータよりも有意に低下した（パラメータをいくら調節しても）
単一モデルで考えることは不可能ではないが、他の心理学的研究からの理論的な証拠を基にした 2 レベルモデルは妥当である

相互作用

- ・ 学習速度の向上
 - Willingham et al.(1989)
完全な顕在的知識を持たない被験者より、完全な顕在的知識を持つものが早く学習した。
 - Stanley et al.(1989)
言語による説明を求めると、被験者の学習は改善した。
すなわち、顕在的知識で生み出される詳細な説明プロセスを通して学習速度が向上した。
 - Mathews et al.(1989)

顕在的、潜在的プロセスの両方が含まれていると学習速度は向上する。

- ・ 学習のパフォーマンス向上
 - Willingham et al.(1989)
タスクを行っているときに発話した被験者は、高いパフォーマンスを獲得する。
発話が顕在知識の形や利用を促す。
 - Gick and Holyoak(1980)
よい問題解決者は問題解決における行動を記述したルールをよりよく述べる事が可能である
 - Chi et al.(1989)
物理のテキストの説明を行った被験者は、新しい問題の解決において高いパフォーマンスを示した。
説明プロセスや顕在知識の利用がパフォーマンスを向上させた
- ・ スキルの転移の促進
 - Willingham et al.(1989)
顕在的宣言的知識が転移を促進するいくつかの証拠
(1) トレーニングタスクにおいて顕在的知識を獲得した被験者は、転移課題でより早い応答をする傾向がある
(2) それらの被験者は転移課題においてより顕在的知識を獲得する
(3) トレーニングタスクと関連のない転移課題のときは、顕在的知識を獲得したそれらの被験者はより遅い反応を示した。これは、前のタスクの顕在的知識が新たなタスクのパフォーマンスに干渉するためであることを示している。
 - Ahlum-Heath and DiVesta(1986)
ハノイの塔を解いている時に発話を求めた被験者はトレーニング後の転移課題において、よい結果を示した。
- ・ 以上の相互作用効果は常にポジティブに働くわけではない
 - 相互作用の効果は特定の状況に依存しており、例えば、過剰発話においてトップレベルの活動が過剰になると、パフォーマンスを害する効果が生まれる
ある特定の状況ではインタラクションは学習において有益なものとなり、CLARION においても実験的に確かめられた(通常条件 vs. 二重課題条件, 通常条件 vs. 発話条件)。
同様の相乗効果は、CLARION に置ける異なる課題にでも見られた(迷路走破課題(Sun et al., 1996; Sun and Peterson, 1998))。

4. 議論

4.1. ボトムアップ vs. トップダウン

- ・ ボトムアップ学習のアドバンテージ
 - 既存の知識、外的に与えられる知識、そして言語的に報告される知識に頼る必要がない
- ・ 本質的にボトムアップスキル学習の多くの場合にトップダウンのプロセスは含まれている
 - 教示を理解するために(例えば、機雷原ナビゲーションタスクにおいて)
 - 事例を理解するために(例えば、泳ぎの学習において)
 - ゲームのルールを獲得するために(例えば、チェスや運転の学習において)
- ・ 正しく適切なア・プリオリな知識(事例,メンタルモデル,理論)は、学習を正しい方向に向かわせ、ボトムアップ学習プロセスが後を引き継ぐ。
トップダウンな事前ルールの理解 ボトムアップな学習
(タスクに対する不適切なア・プリオリな知識は、間違った方向に向かわせ、そして続くボトムアップな学習を妨げる(Stanley et al., 1989))
- ・ CLARION では、これらのプロセスを捉えるため、ア・プリオリな知識の使用が使用可能である。
 - ルールの形成において外的な教示が与えられたとき、モデルは、適切な位置にルールのネットワークを結合させることができ、既存の表象にそれらを結びつけることができる。

4.2. 1レベル vs. 2レベル

- ・ 1レベルのモデルがデータを説明できるならば、2つ目のレベルは必要ないのではないか?
 - 直感的にそして常識的に、顕在的と潜在的な試行の間には違いがある。

- これをサポートする多くの哲学的議論や心理学的データがある
- 一番よい説明は、一つのレベルのアーキテクチャに2つのタイプの知識がインプリメントされるようにつくるよりも、対応する2つのシステムを考えることである
- 相互作用効果は、少なくとも2つのコンポーネントなしには簡単に生成できない

4.3. 潜在 vs. 顕在プラン

- ・ この研究では、逐次的な意思決定において、Q学習を用いた（これは、“潜在的なプランニング”といえる）。“方策”に基づき現在の情報をもとにした意思決定がなされ、方策は将来のステップの価値を暗黙的に取り入れ、さまざまな一連のシーケンスにさらされることを通して学習される。
- ・ しかし、時にはより伝統的なモデルで学習された“顕在的なプランニング”が、スキル獲得における人の学習や意思決定を完全に捉えるために必要になるだろう。
 - “複雑なプランは分割”、“行動後の予測”などの発話データが機雷原ナビゲーション課題から得られている。
 - CLARIONでは顕在的なプランニングには未着手だが、プランニングに必要な情報はボトムレベルにすでに存在している。
例：ボトムレベルから、各状況における適応すべき最適なルールが何であるかに関する確率的情報が与えられるため、可能な系列を顕在的に探索することを通して顕在的なプランを構成することが可能である。

4.4. 比較

スキル学習

トップダウンのプロセスとしてスキル学習

- ・ Jhon et al.(1994)
プロダクションルールを用いて Nintendo のゲームに対してエキスパートのパフォーマンスと同等の学習をモデル化した（サブゴールとチャンキングを使って SOAR を使いモデル化されている）。多くの事前知識がモデルには要求された。
- ・ Gelfand et al.(1989)
顕在的なフォームにおいてすべての知識をコード化し、そして、練習を通して知識がニューラルネットワークに吸収されるロボットのスキル学習に対するモデルを提案した。最終的に、ネットワークは潜在的な手続きの形でタスクを行うためのスキルを獲得する事ができた。
- ・ Schneider and Oliver(1991)
論理回路を判定するスキルを学習するハイブリッドなコネクショニストモデル。よく考えられた計算が、繰り返される試行を通して行われだけでなく、自動化されたプロセス（潜在的プロセス）が後を引き受ける。

より高次のスキルの領域

高次のスキル学習のモデルのほとんどはトップダウンでルールベースである。

- ・ チェス
初期の研究領域の一つはチェスであり、Simon によって研究された。手段-目標方略が使用される状態空間におけるサーチをベースにしている。
- ・ 初等数学の学習
教示から得られた宣言的知識を変化することにより学習が行われる。そしてたやすく使うことができる数学的手続きへの事例が形成される。

スキル学習の事例ベース理論

一般的に、ボトムアップの種類である。

CLARION のボトムレベルの活動が事例ベースまたはプロトタイプベースとして考えることができる。

- ・ Logan(1988)
ある状況に遭遇したとき、潜在的に関連する過去の事例が検索され、事例をベースにして応答が行われる。しかしながら、新規な状況では関連する事例がないため顕在的な推論が行われる。

- Stanley et al.(1989)
主に過去の事例の記憶に関連した潜在的な学習/実行が行われる。それらの事例は現在の状態とそれを比較することによって利用される。
- これ以外にも認知的動機のないボトムアップ学習モデルは多数存在する (e.g., GA や強化学習)

概念学習モデル

- 共通点
” ルール+例外 ” のアイデアが基本的に ” ルール+ネットワーク ” の CLARION のアーキテクチャに類似している。
- 明らかな違い
シーケンシャルなスキルに対して振舞えない。

認知アーキテクチャ

- ACT* (Anderson, 1982, 1983, 1993)
 - 意味ネットワーク (宣言的知識) とプロダクションシステム (手続き的知識) からなる。
 - 宣言的知識の手続き化を通してプロダクションが形成される。
 - トップダウン学習, 宣言的/手続き的知識双方ともにシンボリックな形式である。
- SOAR(Rosenbloom et al., 1993)
 - 問題空間のアイデアを基礎にしている。
 - SOAR では知識の 2 つのタイプを区別しない。スキルの上達はチャンキングによって説明される。

5. まとめ

- ボトムアップのスキル学習へのアプローチを議論し, このアプローチのデモンストレーションとしてハイブリッドのコネクショニストモデルについて議論した。
- ボトムレベルにおける潜在的学習とパフォーマンスが, 少なくとも低次のスキルの領域においては主要であり, 本質的である。
- 潜在/顕在の違いはモデルの 2 つのレベルの間の表象的な違いによって説明される。
- モデルは, 既存の解釈とは異なるスキル学習の方法の可能性を示唆した。
- 既存の学習モデルとの比較は, 本アプローチが他のアプローチやモデルでは捉えられないボトムアップの現象と, 宣言的と手続き的知識の連続的なインタラクションを示した。
- このモデルを用い, 機雷原ナビゲーションタスクにおけるモデルと人のパフォーマンスの比較を実験的に行った。
- 実験的操作を通して, 間接的な方法で 2 つのレベルの相対的寄与を示した。
- モデルと人のデータの間的一致が有意であった。
- この研究の欠点は, 人の被験者とのより詳細な一致を欠いていることである。
 - 将来的なより良い実験手法の開発によって対処する。